

# Τυπολογιστική Νοημοσύνη

Ιωάννης Γ. Τσούλος

Τμήμα Πληροφορικής και τηλεπικοινωνιών  
Πανεπιστήμιο Ιωαννίνων

2024

# Περίληψη

## 1 Ομαδοποίηση

- Βασικά στοιχεία
- Κριτήρια ομοιότητας

## 2 Ο αλγόριθμος KNN

- Βασικός αλγόριθμος
- Επεκτάσεις

## 3 Μετρήσεις σφάλματος

## 4 Ο αλγόριθμος KMEANS


## Ορισμός

Στην ομαδοποίηση “έξυπνοι” αλγόριθμοι χρησιμοποιούνται για την κατάταξη δεδομένων σε ένα προκαθορισμένο αριθμό κατηγοριών. Για παράδειγμα αν διαθέτουμε πολλά δείγματα κρασιών και θέλουμε να τα κατατάξουμε σε κατηγορίες με βάση χαρακτηριστικά τους (πχ οξύτητα, χρώμα κτλ)

# Προϋποθέσεις

- ➊ Η ομάδα να ειναι ομοιογενής, δηλαδή τα στοιχεία που απαρτίζουν μια ομάδα να είναι όσο το δυνατόν πιο κοντά μεταξύ τους
- ➋ Οι ομάδες να απέχουν, δηλαδή να μην είναι “κοντά”, γιατί αλλιώς θα πρέπει να ενωθούν σε μια.

## Παράδειγμα



## Παράδειγμα ομαδοποίησης

# Παραδείγμα.

- Δεδομένα που ανήκουν σε τρεις κατηγορίες
- Σκοπός της μεθόδου θα πρέπει να είναι ο διαχωρισμός των γκρίζων σημείων σε κάποια από τις περιοχές αυτές
- Κάποια σημεία είναι ξεκάθαρο σε ποια ομάδα πρέπει να μπουν
- Κάποια σημεία βρίσκονται ανάμεσα στις περιοχές και δεν είναι ξεκάθαρο σε ποια περιοχή πρέπει να μπουν
- Σε κάποιες περιπτώσεις ενδεχομένως να χρειαστεί να αλλαξει το πλήθος των ομάδων (αύξηση ή μείωση).

## Ορισμοί.

Για να μπορέσουμε να αξιολογήσουμε πόσο κοντά βρίσκονται τα δεδομένα θα πρέπει να υπάρχει κάποιο κριτήριο ομοιότητας. Σε όλες τις εκφράσεις που ακολουθούν ο αριθμός  $n$  εκφράζει την διάσταση (πλήθος χαρακτηριστικών) κάθε προτύπου. Μερικά γνωστά κριτήρια παρουσιάζονται στην συνέχεια.

## Ευκλείδια απόσταση.

- Σε όλες τις εκφράσεις θεωρούμε πως στους τύπους έχουμε διανύσματα
- Η μεταβλητή  $n$  αναπαριστά την διάσταση του προβλήματος (διάσταση προτύπων)
- Είναι το πιο γνωστό κριτήριο απόστασης.

$$D(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

# Πίνακας ευκλίδειας απόστασης


- ① Είναι ο πίνακας των αποστάσεων μεταξύ διανυσμάτων.
- ② Χρησιμοποιείται σε πολλές μεθόδους.
- ③  $A = (a_{ij})$ ,  $a_{ij} = d_{ij}^2 = \|x_i - x_j\|^2$
- ④  $A_{ij} = 0$ ,  $\forall i = j$
- ⑤  $A_{ij} = A_{ji}$ , συμμετρικός πίνακας
- ⑥  $A_{ij} \geq 0$

## Απόσταση Manhattan.

- ① Βασίζεται σε παρατηρήσεις σχετικά με τις αποστάσεις στην τετραγωνισμένη περιοχή του Μανχάτταν
- ② Η απόσταση αυτή δίνεται από την εξίσωση

$$D(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (2)$$

# Απόσταση Manhattan (σχήμα)



Κόκκινο χρώμα: Απόσταση Manhattan distance. Πράσινο: Απευθείας μετακίνηση. Λοιπά χρώματα: Ισοδύναμες αποστάσεις Manhattan

# Μέγιστης διαφοράς.

- ① Το κριτήριο αυτό βασίζεται στην εύρεση της μέγιστης διαφοράς σε όλες τις διαστάσεις των προτύπων
- ② Χρησιμοποιείται αρκετά τακτικά όπως και της Ευκλείδιας απόστασης.
- ③ Δίνεται από την εξίσωση

$$D(x, y) = \max_{i=1}^n |x_i - y_i| \quad (3)$$

## Συνημιτονοειδής ομοιότητα.

Ορίζεται από την εξίσωση

$$D(x, y) = \frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2} \sqrt{\sum_{i=1}^n y_i^2}} \quad (4)$$


## Ορισμοί

- Η μέθοδος αναπτύχθηκε από τους Fix και Hodges το 1951[1].
- Μη παραμετρική μέθοδος, δηλαδή δεν υπάρχουν παράμετροι που πρέπει να εκτιμηθούν.
- Τα δεδομένα κατατάσσονται στην κατηγορία που πλειοψηφεί ανάμεσα στους K κοντινότερους γείτονες τους.
- Παίζει σημαντικό ρόλο η τιμή του K ( αριθμός γειτόνων)
- Παίζει λιγότερο σημαντικό ρόλο το είδος της απόστασης που θα χρησιμοποιηθεί.
- Μπορεί να χρησιμοποιηθεί τόσο για κατηγοριοποίηση δεδομένων όσο και για μάθηση συναρτήσεων.
- Είναι ανεκτικός αλγόριθμος σε παρουσία θορύβου και όταν ακόμα λείπουν τιμές από χαρακτηριστικά.

- ① Δημιουργία συνόλου εκπαίδευσης  $S = \{X_1, X_2, \dots, X_N\}$ , όπου  $X_i \in R^d$
- ② Καθορισμός της παραμέτρου  $K$ . Συνήθως οι τιμές αυτής της παραμέτρου είναι μονοί αριθμοί.
- ③ Για κάθε νέο πρότυπο  $X$ ;
  - ① Δημιουργία του συνόλου  $S_x$  με τους  $K$  κοντινότερους γείτονες από το σύνολο  $S$ . Για την εύρεση των γειτόνων χρησιμοποιούνται διάφορα κριτήρια απόστασης με το πιο συνηθισμένο την **Ευκλείδια** απόσταση.
  - ② Εύρεση της κατηγορίας  $\gamma$  που πλειοψηφεί στο σύνολο  $S_x$ .
  - ③ Ανάθεση του προτύπου στην κατηγορία  $\gamma$ .
- ④ Ο αλγόριθμος βασίζεται στο  $K$ . Επίσης είναι σχετικά αργός αλγόριθμος, αφού απαιτεί ταξινόμηση για κάθε πρότυπο.
- ⑤ Πιθανή λύση η δημιουργία πίνακα απόστασεων (όπως ο πίνακας Ευκλείδιας απόστασης).

# Μάθηση συναρτήσεων

- ① Με τον όρο μάθηση συναρτήσεων μιλάμε για εύρεση της καμπύλης (συνάρτησης) που πιθανόν να βρίσκεται πίσω από δεδομένα.
- ② Σκοπός ενός μοντέλου που κάνει μάθηση συναρτήσεων είναι η εκτίμηση της συνάρτησης που περνά από αυτά τα σημεία αλλά και από άλλα ενδιάμεσα σημεία και πιθανόν και από σημεία εκτός του διαστήματος.




③

## Χρήση KNN για μάθηση συναρτήσεων

- ① Δημιουργία συνόλου εκπαίδευσης  $S = \{X_1, X_2, \dots, X_N\}$ , όπου  $X_i \in R^d$
- ② Καθορισμός της παραμέτρου  $K$ . Συνήθως οι τιμές αυτής της παραμέτρου είναι μονοί αριθμοί.
- ③ Για κάθε νέο πρότυπο  $X$ ;
  - ① Δημιουργία του συνόλου  $S_x$  με τους  $K$  κοντινότερους γείτονες από το σύνολο  $S$ . Για την εύρεση των γειτόνων χρησιμοποιούνται διάφορα κριτήρια απόστασης με το πιο συνηθισμένο την **Ευκλείδια** απόσταση.
  - ② Υπολογισμός της τιμής

$$Y(x) = \frac{1}{K} \sum_{i=1}^K X_i, \forall X_i \in S_x$$

# Παράδειγμα μάθησης συναρτήσεων



Για το προηγούμενο σύνολο δεδομένων με χρήση KNN

# Παράδειγμα εύρεσης κατηγοριών

- ① Αρχικό σύνολο δεδομένων



- ② Χρήση ενός γείτονα



- ③ Χρήση 5 γειτόνων



- ① Για  $K=1$  δεν έχουμε τόσο καλή συμπεριφορά, καθώς κάνει πολλά λάθη
- ② Για μεγαλύτερες τιμές του  $K$ , με  $K$  περιττό παρατηρείται καλύτερη συμπεριφορά
- ③ Για πολύ μεγάλες τιμές γίνονται πάλι λάθη, καθώς συμμετέχουν στην ψηφοφορία και πολύ μακρινά σημεία

# KNN με χρήση βαρών

- Έχει παρουσιάσει καλύτερες ικανότητες μάθησης σε αρκετά παραδείγματα
- Συσχετίζουμε κάθε γείτονα με ένα βάρος
- Έχουν αναπτυχθεί αρκετές τεχνικές KNN με βάρη
- Στην συνέχεια παρουσιάζεται η τεχνική Inverse Weighted KNN[2]

# KNN με βάρη

- ① Για ένα πρότυπο  $x_i$  εύρεση των αποστάσεων  $d_j, j = 1..K$
- ② Για κάθε απόσταση  $d_j$  υπολογισμός της ποσότητας  $V_j = \frac{1}{d_j}$
- ③ Υπολογισμός των βαρών  $w_j = \frac{V_j}{\sum V_k}$
- ④ Ανάθεση του προτύπου στην κατηγορία με το μεγαλύτερο άθροισμα βαρών

- ① Για κάθε πρότυπο  $x_i$  δημιούργησε την λίστα  $L(x_i)$  με τους  $k$  κοντινότερους γείτονες.
- ② Για κάθε ζεύγος σημείων  $x_i$  και  $x_j$ 
  - ① Αν  $L(x_i) \cap L(x_j) \geq M$ , τοποθέτησε τα δύο σημεία  $x_i$  και  $x_j$  στην ίδια ομάδα
- ③ Η διαδικασία επαναλαμβάνεται μέχρι να μην υπάρχουν πλέον άλλα σημεία εκτός ομάδας.

Αυτός ο αλγόριθμος στηρίζεται στις παραμέτρους  $k$  και  $M$

## Regression Error

- ① Είναι το σφάλμα που μας ενδιαφέρει για μάθηση συναρτήσεων (προσαρμογή δεδομένων)
- ② Χρησιμοποιείται για να μετρήσει το σφάλμα ενός μοντέλου μάθησης  $\Psi(x)$
- ③ Σκοπός του μοντέλου είνα να “μαντέψει” τις σωστές εξόδους  $y_i$ ,  $i = 1, \dots, m$
- ④ Ορίζεται ως

$$E_R(\Psi(x)) = \frac{1}{m} \sum_{i=1}^m (\Psi(x_i) - y_i)^2$$

- ⑤ Αποτυπώνει το μέσο τετραγωνικό σφάλμα ανά σημείο.

# Classification Error

- ① Μετράει την μέση διαφοροποίηση σε προβλήματα ταξινόμησης ανάμεσα στην εκτιμούμενη κατηγορία και την πραγματική
- ② Θεωρούμε το μοντέλο  $\Psi(x)$
- ③ Το μοντέλο είτε παράγει κατηγορία είτε την εκτιμούμε με χρήση κατωφλίων πχ  $C(x)$
- ④ Ορίζεται ως

$$E_C(\Psi(x)) = \frac{1}{m} \sum_{i=1}^n (C(\Psi(x_i)) \neq y_i)$$

## Confusion matrix


- ① Αν έχουμε  $N$  κατηγορίες τότε έχει διάσταση  $N \times N$
- ②  $C_{ij}$ =Πλήθος προτύπων που ενώ ανήκουν στην κατηγορία i ανατέθηκαν στην κατηγορία j
- ③ Άθροισμα στοιχείων κύριας διαγωνίου: Πόσα στοιχεία έχουν ταξινομηθεί σωστά
- ④ Άθροισμα των υπολοίπων στοιχείων: Πόσα στοιχεία έχουν ταξινομηθεί λάθος

# Precision και Recall

① Precision:  $p = \frac{tp}{tp+fp}$

② Recall:  $r = \frac{tp}{tp+fn}$

③ Σχηματικά (2 κατηγορίες):



How many retrieved items are relevant?

$$\text{Precision} = \frac{\text{true positives}}{\text{true positives} + \text{false positives}}$$

How many relevant items are retrieved?

$$\text{Recall} = \frac{\text{true positives}}{\text{true positives} + \text{false negatives}}$$

- ① Δημιουργία εκπροσώπων από ομάδες.
- ② Έχει υλοποιηθεί αρχικά από τον MacQueen [3].
- ③ Το πλήθος των ομάδων θεωρείται δεδομένο.
- ④ Έχουν αναπτυχθεί δεκάδες παραλαγές του αλγορίθμου από τότε.

# Ο αλγόριθμος

① **Αρχικοποίηση** των  $K$  κέντρων  $c_i$ ,  $i = 1..K$ , όπου  $K$  είναι το εκτιμούμενο πλήθος ομάδων. Κάθε κέντρο  $c_i$  θεωρούμε πως έχει  $n$  στοιχεία, όπου  $n$  είναι η διάσταση των προτύπων εισόδου.

② **Επανέλαβε**

- ①  $S_i = \{\}$ ,  $i = 1..K$
- ② Εύρεση της ομάδας που ανήκει το κάθε στοιχείο  $x_i$ ,  $i = 1..N$ :  
α) εύρεση  $j^* = \min_{i=1}^K \{D(x_i, c_j)\}$  β)  $S_{j^*} = S_{j^*} \cup x_i$
- ③ Ανανέωση του κέντρου της ομάδας

$$c_j = \frac{1}{M_j} \sum_{x_i \in S_j} x_i \quad (5)$$

όπου  $M_j$  το πλήθος των μελών της ομάδας  $j$ .

④ Αν τα κέντρα δεν έχουν αλλάξει **τότε τερματισμός**,  
**αλλιώς** μετάβαση στο βήμα 2.

# Σύνοψη

- Παρουσιάστηκαν η έννοια της κατηγοριοποίησης
- Παρουσιάστηκε ο αλγόριθμος KNN και οι επεκτάσεις του
- Δόθηκε μια σύντομη παρουσίαση του αλγορίθμου KMEANS

# Βιβλιογραφία |

-  Fix, Evelyn; Hodges, Joseph L. (1951). Discriminatory Analysis. Nonparametric Discrimination: Consistency Properties (PDF) (Report). USAF School of Aviation Medicine, Randolph Field, Texas.
- 
- <https://visualstudiomagazine.com/articles/2019/04/01/weighted-k-nn-classification.aspx>
-  MacQueen, J.: Some methods for classification and analysis of multivariate observations, in: Proceedings of the fifth Berkeley symposium on mathematical statistics and probability, Vol. 1, No. 14, pp. 281-297, 1967.